

DOI:10.11918/202207039

基于 ConvLSTM 的空间进动锥体目标 HRRP 序列预测

李宏博^{1,2}, 吴文华^{1,2}, 张云^{1,2}

(1. 哈尔滨工业大学 电子与信息工程学院, 哈尔滨 150001;
2. 对海监测与信息处理工信部重点实验室(哈尔滨工业大学), 哈尔滨 150001)

摘要: 宽带雷达对空间进动锥体目标进行持续探测能够形成高分辨距离像 (high resolution range profile, HRRP) 序列。HRRP 序列携带空间进动锥体目标的空间几何信息和运动规律等信息, 是进行目标关联跟踪和分类识别的重要依据, 因此研究空间进动锥体目标的 HRRP 序列预测具有重要意义。卷积长短时记忆 (ConvLSTM) 网络将 CNN 和 LSTM 二者的特点有效结合, 能够充分挖掘 HRRP 序列的空间和时间特性, 完成对 HRRP 的预测。本文基于空间锥体目标的进动模型建立了多种尺寸、运动速度和运动方向等不同参数的 HRRP 序列数据集, 并利用此数据集根据 HRRP 特性设计实现了适用于空间进动锥体目标 HRRP 预测的 ConvLSTM 网络模型。为了测试本文设计的 ConvLSTM 网络预测效果, 将 ConvLSTM 网络与二维卷积神经网络模型进行预测效果对比分析。仿真实验结果表明, ConvLSTM 网络预测结果与物理光学法计算得到的 HRRP 一致性高, 皮尔逊相关系数高达 0.973 1, 平均绝对误差低至 0.033 4, 相较于二维卷积神经网络预测结果更加准确。证明本文设计的 ConvLSTM 网络模型能够有效提取 HRRP 序列的时间和空间特征, 实现对 HRRP 序列的高精度预测。

关键词: 高分辨距离像; 预测; ConvLSTM; 空间目标; 进动

中图分类号: TN975 文献标志码: A 文章编号: 0367-6234(2023)10-0010-09

HRRP sequence prediction for spatial precession cone target based on ConvLSTM

LI Hongbo^{1,2}, WU Wenhua^{1,2}, ZHANG Yun^{1,2}

(1. School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin, 150001, China;
2. Key Lab of Ocean Monitoring and Information Processing, Ministry of Industry and Information Technology (Harbin Institute of Technology), Harbin 150001, China)

Abstract: Continuous detection of space precession cone targets using broadband radars can generate high-resolution range profile (HRRP) sequences. The HRRP sequences contain information such as spatial geometric information and precession laws of space cone targets, which are applicable to target association, tracking and classification. Therefore, it is of great significance to perform HRRP sequence prediction for spatial precession cone targets. The ConvLSTM network effectively combines the characteristics of CNN and LSTM, which can fully mine spatial and temporal information of HRRP sequences to achieve prediction of HRRP. This article establishes a HRRP sequence dataset based on the precession model of spatial cone targets, which incorporates different parameters such as size, motion speed and motion direction, and uses this dataset to design and implement a ConvLSTM network model suitable for HRRP prediction for spatial precession cone targets according to HRRP characteristics. In order to validate the predictions by the ConvLSTM network designed in this paper, the ConvLSTM network is compared with the two-dimensional convolutional neural network mode. Simulation and experimental results show that ConvLSTM network is in good agreement with HRRP calculated using physical optics method, and is more accurate than predictions of 2D convolutionneural network. The Pearson correlation coefficient is as high as 0.973 1, and average absolute error reaches 0.033 4. The ConvLSTM network model can effectively extract temporal and spatial features of HRRP sequences to achieve high-precision prediction of HRRP sequences.

Keywords: high resolution range profile; prediction; ConvLSTM; spatial target; precession

高分辨距离像 (high resolution range profile, HRRP) 携带雷达径向方向的目标距离维信息, 包含目标形状特征, 如目标的尺寸、目标散射点分布情况

等, 常用于雷达目标的分类识别, 是国内外雷达领域的研究热点^[1-3]。空间锥体是一种常见的雷达目标, 在空间中除了平动以外, 往往伴随进动和章动等

收稿日期: 2022-07-09; 录用日期: 2022-11-01; 网络首发日期: 2023-04-27

网络首发地址: <http://kns.cnki.net/kcms/detail/23.1235.T.20230427.1505.014.html>

作者简介: 李宏博(1980—), 女, 正高级工程师, 博士生导师; 张云(1975—), 女, 教授, 博士生导师

通信作者: 张云, zhangyunhit@hit.edu.cn

微动。对空间进动锥体目标进行连续成像处理可以获得一维距离像序列, 研究人员常常通过分析空间锥体目标的一维距离像序列的调制特性来提取微动参数^[4]。一维距离像序列变化主要受锥体平动和进动影响, 平动往往具有很强的规律性, 对于进动而言, 从连续多次成像结果中可以发现, 一维距离像的强散射点的位置会产生周期性变化, 与目标进动规律一致^[5]。因此, 理论上空间进动锥体的一维距离像序列预测能够实现。

高分辨距离像序列预测即根据已知的若干帧高分辨距离像, 学习并预测之后的高分辨率距离像。单帧一维距离像携带目标的径向距离信息, 连续多帧一维距离像序列具有较强的前后时间关联特性, 类似于视频预测, 这就要求网络模型既能够提取一维距离像的空间信息, 又能够挖掘一维距离像序列时间上含有的目标运动规律。

光流法^[6]是计算机视觉领域经典的预测算法, 基于亮度恒定(同一目标在不同帧间运动时, 其亮度不会发生改变)、时间连续性(时间的变化不会引起目标位置的剧烈变化, 相邻帧之间位移较小)两个假设, 利用图像像素在时间域上的变化信息计算物体的运动情况实现图像的预测。对于空间进动锥体而言, 不满足亮度恒定和时间连续性假设, 光流法难以适用。近年来, 神经网络迅速崛起, 具有泛化性能好、数据挖掘能力强等优点, 广泛应用于数据预测领域。其中循环神经网络(RNN)能够记忆历史输入数据, 主要用于处理时间序列, 但 RNN 存在梯度消失或爆炸以及对长期信息不敏感问题^[7]。针对 RNN 的不足, 长短时记忆网络(LSTM)增加了门控设置, 能够很好地处理长序列问题, 能够有效地提取时间序列信息^[8]。但对于包含空间信息的时间序列而言, LSTM 适应性明显降低, 难以进行处理。而卷积网络(CNN)则可以有效地提取图像中的空间信息, 因此有学者将卷积神经网络应用于图像预测问题, 某些场景中也取得了不错的效果^[9]。在此基础上, 文献[10]提出了卷积长短时记忆模型(convolutional long short-term memory, ConvLSTM), 该模型具有预测携带有时空信息数据的能力, 能够学习到数据隐含的时间和空间关联信息。

文献[10-11]已将 ConvLSTM 方法应用于气象雷达进行临近天气预测。针对宽带雷达观测空间进动锥体目标获得的高精度一维距离像的特点, 本文将该网络算法应用于 HRRP 序列预测分析, 为了提高网络空间特征提取的能力, 在 ConvLSTM 网络提取到时空信息之后加入二维卷积网络(Conv2d), 并采用二值交叉熵作为损失函数, 能够在有效提取数

据特征的同时缩短模型收敛时间。本文建立空间进动锥体 HRRP 序列仿真数据集, 在时空尺度上采用 ConvLSTM 网络进行预测分析, 并与经典二维卷积神经网络预测结果对比。实验结果表明, 本文设计的网络模型能够实现高分辨距离像的预测, 并具有较好的预测性能。

1 空间进动锥体一维距离像成像

空间锥体目标通常会采用绕轴线旋转的方式来确保发射的稳定性和提高命中率, 但是锥体在自旋过程中不可避免地会受到横向扰动, 进而产生进动。空间锥体的进动由绕锥体对称轴的自旋运动和围绕进动轴的锥旋运动复合而成。如图 1 所示, 以雷达位置为原点建立雷达坐标系 $Q-U'V'W'$, 参考坐标系 $O-U'V'W'$ 与雷达坐标系平行, 本体坐标系 $O-XYZ$ 固连在锥体目标上, 以锥体旋转对称轴为 OZ 轴, 参考坐标系与本体坐标系都以锥体目标重心为原点。锥体目标围绕自身对称轴 OZ 轴做自旋运动, 同时 OZ 轴围绕进动轴 ON 以角速度 ω 进动, 进动角为 θ , γ 为雷达视线与进动轴夹角, 即俯仰角。 α 为雷达视线内侧与自旋轴之间的夹角, 即姿态角。

设雷达发射线性调频脉冲信号 $s(t)$, 其表达式为

$$s(\hat{t}, t_m) = \text{rect}\left(\frac{\hat{t}}{T}\right) e^{j2\pi(f_0\hat{t} + \frac{\gamma}{2}\hat{t}^2)} \quad (1)$$

式中: \hat{t} 为快时间, t_m 为慢时间, $t = \hat{t} + t_m$; f_0 为载波频率; T 为脉冲宽度; $\text{rect}\left(\frac{t}{T}\right)$ 为矩形信号; $\gamma = \frac{B}{T}$ 为调频斜率; B 为信号带宽。

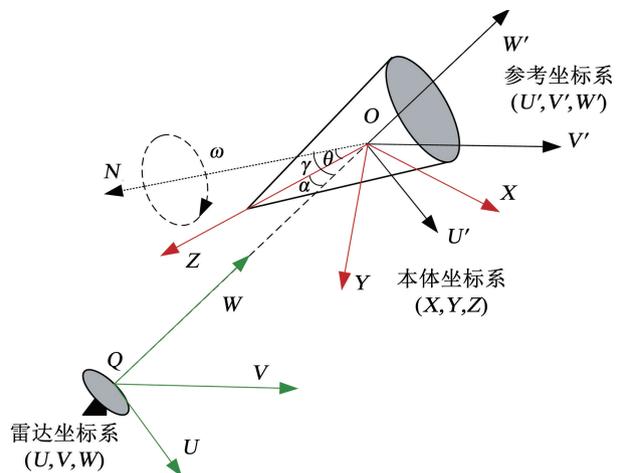


图 1 空间锥体进动模型

Fig. 1 Space cone precession model

经过解线性调频处理和消除残余项后, 进行傅里叶变换可得到一维距离像回波^[12]为

$$s_c(r, t_m) = \sum_{i=1}^N \sigma_i \exp(-j4\pi R_{\Delta i}(t_m)/\lambda_c) \cdot \text{sinc}\left[\frac{2B}{c}(r - R_{\Delta i}(t_m))\right] \quad (2)$$

式中: $R_{\Delta i} = R_i(t) - R_{\text{ref}}(t_m)$, $R_i(t)$ 为第 i 个散射点的距离; N 为散射点个数; $\text{sinc}(\cdot)$ 为辛格函数; σ_i 为第 i 个散射点的 RCS; λ_c 为载波中心频率对应波长。

2 基于 ConvLSTM 的一维距离像预测方法

2.1 ConvLSTM 网络基本结构

ConvLSTM 是基于 LSTM 网络发展起来的, 能够直接处理二维数据。模型中的卷积运算主要负责提取数据中包含的空间信息, 而 LSTM 结构善于处理时间序列数据, ConvLSTM 网络将二者特点有效结

合, 能够学习到时间和空间两个维度特征。如图 2 所示, 传统 LSTM 网络模型采用全连接的方式实现状态转换, 而 ConvLSTM 网络模型通过将卷积运算应用于 LSTM 的“输入到状态”和“状态到状态”两部分以改进 LSTM, 通过多层卷积操作提取输入和状态的空间特征, 以决定在每个空间位置上的状态变量和输入信息的取舍, 然后采用 LSTM 相似的门控单元控制当前输入特征的传递, 确定当前时刻的输出^[13]。对于空间进动锥体目标的一维距离像序列, ConvLSTM 网络中的卷积状态转换能够提取目标的空间(目标形状)信息, LSTM 序列处理能够有效提取到目标的一维距离像随时间变化的有效信息(包括受重力和进动影响导致像的形状的变化), ConvLSTM 网络适用于空间进动锥体一维距离像序列的预测问题。

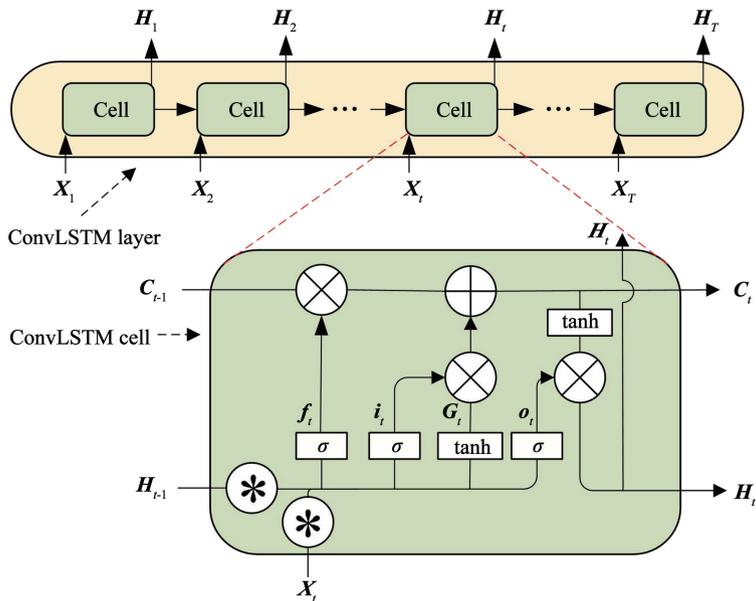


图 2 ConvLSTM 结构

Fig. 2 Structure of ConvLSTM

从图 2 可以看到, ConvLSTM 单元包含遗忘门(f_t)、输入门(i_t)和输出门(o_t), 通过这些门来调控数据信息的获取并更新单元状态。各个门之间的传递关系为:

$$i_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + b_i) \quad (3)$$

$$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + b_f) \quad (4)$$

$$o_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + b_o) \quad (5)$$

$$G_t = \tanh(W_{xg} * X_t + W_{hg} * H_{t-1} + b_g) \quad (6)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot G_t \quad (7)$$

$$H_t = o_t \cdot \tanh(C_t) \quad (8)$$

式中: “ \cdot ” 为矩阵对应元素相乘; “ $*$ ” 为卷积运算; σ 为 sigmoid 激活函数; i_t 为输入门, 它采用激活函数对输入数据与上一节点输出数据进行选择性接收, 决定了当前节点数据的输入; f_t 为遗忘门, 主要

作用是决定对上一节点输出数据的遗忘比例; C_t 为 t 时刻神经元的单元状态, 它是上一节点单元状态与当前输入数据综合后的结果; G_t 为当前时刻积累的信息; o_t 为输出门, 主要控制当前单元状态的输出比例, 输出结果即为本次单元输出 H_t 。

2.2 ConvLSTM 网络模型设计

2.2.1 数据预处理

应对 HRRP 幅度敏感性问题, 对每帧 HRRP 都进行取模运算, 并按 min-max 方式进行归一化处理。因为 ConvLSTM 网络最后一层采用 softmax 激活, 归一化到 $[0, 1]$ 范围内有利于数据处理。归一化公式为

$$x_{\text{norm}} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (9)$$

式中: \mathbf{x}_{norm} 为归一化后的一维距离像数据向量, \mathbf{x} 为归一化前的一维距离像数据向量。

假设使用前 m 帧 HRRP 数据预测后 n 帧, 即采用大小为 $m+n$ 的滑动窗口对 HRRP 序列进行遍历。

$$\mathbf{S}_i = [\mathbf{x}_i, \mathbf{x}_{i+1}, \dots, \mathbf{x}_{i+m-1}] \quad (10)$$

$$\mathbf{l}_{\text{label}_i} = [\mathbf{x}_{i+m}, \mathbf{x}_{i+m+1}, \dots, \mathbf{x}_{i+m+n-1}] \quad (11)$$

式中: $i=1, 2, \dots, N-m-n+1, N$ 为原 HRRP 序列长度; \mathbf{S}_i 为第 i 个训练样本矩阵; $\mathbf{l}_{\text{label}_i}$ 为第 i 个训练样本对应的标签矩阵。

如图 3 所示, 假设每帧 HRRP 的距离单元个数为 M , 对每个 HRRP 序列样本都进行这样的滑动处理即可得到所需的样本集和标签。这样的处理也起到了增广数据的作用, 对一个长度为 N 的 HRRP 序列进行上述的滑动窗口处理, 可以得到 $N-m-n+1$ 个样本。图 4 为利用滑动窗口的方式创建的样本和标签示例, 图中为第 2 个样本和标签即 $i=2$, 采用 16 帧样本预测 1 帧, 即 $m=16, n=1$ 。

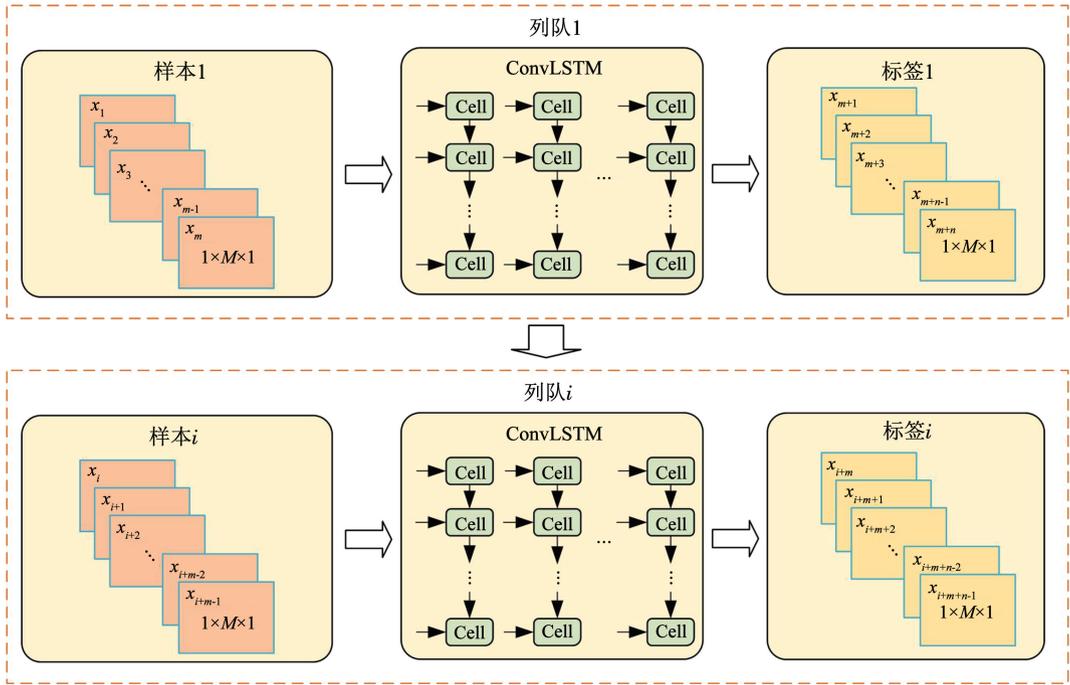


图 3 滑动窗口处理示意
Fig. 3 Sliding window processing

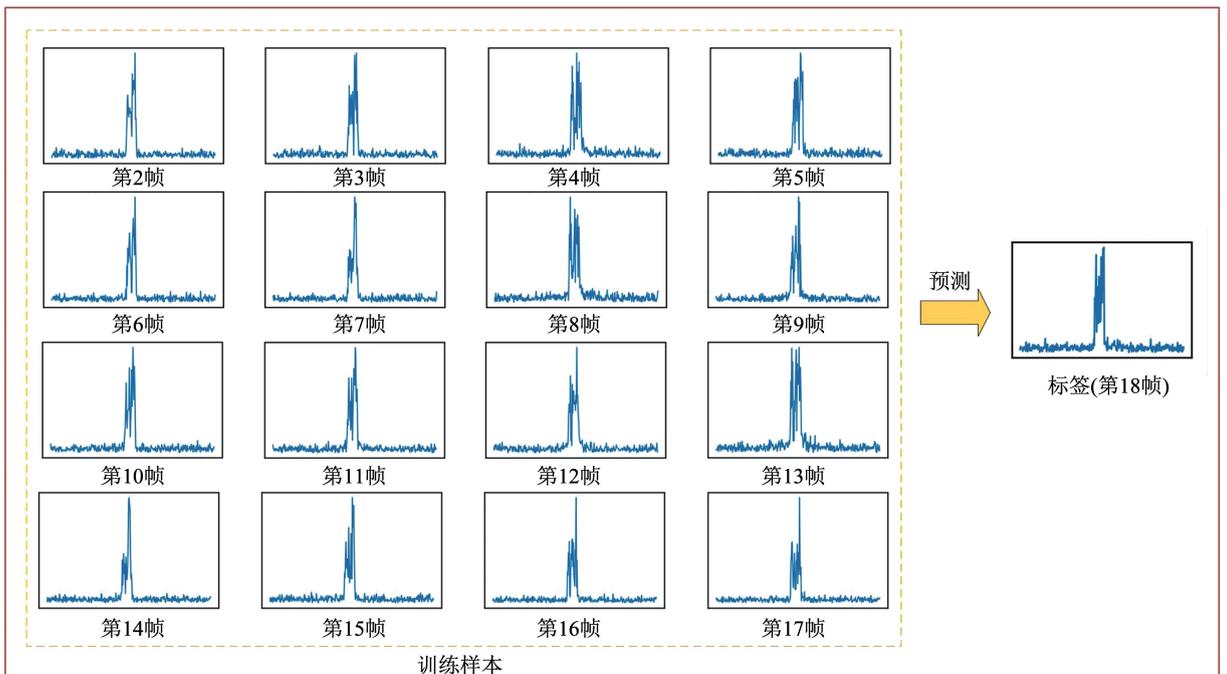


图 4 样本和标签数据示例
Fig. 4 Sample and labeled data examples

ConvLSTM 模型主要是为二维影像数据而设计的^[14],因此需要按照影像数据形式对输入数据重排列。ConvLSTM 网络输入为五维张量,尺寸为 (samples, time, rows, cols, channels),其中 time 为输入数据时间步长。若进行多步预测输出也为五维张量,尺寸为 (samples, timesteps, output_row, output_col, filters),其中 timesteps 为待预测时间步长;若进行单步预测,输出为四维张量,尺寸为 (samples, output_row, output_col, filters)。单帧距离像维度为 $1 \times M$,将其排列为 $1 \times M \times 1$ 图像形式的三维张量作

为网络输入的基本单元,3 个维度分别为图像的长、宽和通道。对于 k 组包含 m 个时间步的数据来说,训练数据应该重排列为 $k \times m \times 1 \times M \times 1$ 。同理,为了保持输出数据尺寸的一致性,训练样本标签也需要进行上述重排列。

2.2.2 网络结构

本文提出的 HRRP 序列 ConvLSTM 预测网络结构见图 5。为了提取数据的高层次时序特征,模型采用 4 层 ConvLSTM 层和 1 层二维卷积层。

网络各层输出数据大小和参数数量见表 1。

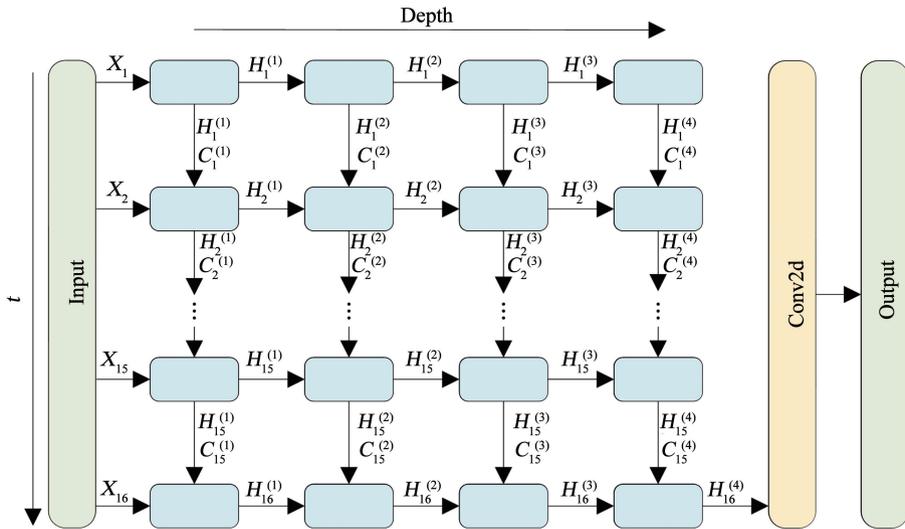


图 5 ConvLSTM 预测模型结构

Fig. 5 Structure of ConvLSTM prediction model

表 1 网络模型结构参数

Tab. 1 Network model structural parameters

网络层	输出尺寸	训练参数量
convlstm_1 (ConvLSTM)	(None, None, 1, 360, 30)	37 320
BatchNormalization_1	(None, None, 1, 360, 30)	120
convlstm_2 (ConvLSTM)	(None, None, 1, 360, 30)	72 120
BatchNormalizationn_2	(None, None, 1, 360, 30)	120
convlstm_3 (ConvLSTM)	(None, None, 1, 360, 30)	72 120
BatchNormalization_2	(None, None, 1, 360, 30)	120
convlstm_4 (ConvLSTM)	(None, 1, 360, 30)	72 120
BatchNormalization_3	(None, 1, 360, 30)	120
conv2d (Conv2d)	(None, 1, 360, 1)	301

数据流经过 ConvLSTM 网络单元时,经过卷积运算后输出数据的最后一个维度大小取决于卷积操作过程中卷积核的个数。每帧一维距离像包含 360 个距离单元,每层 ConvLSTM 层包含 30 个卷积核,因此输出数据的最后一个维度为 30,在 4 层

ConvLSTM 层后加入只包含一个卷积核的二维卷积层对 ConvLSTM 网络输出数据进行特征提取,将输出数据的最后一个维度降为 1,该二维卷积层采用 sigmoid 激活函数激活,使输出数据大小映射到 0 ~ 1 范围内。模型采用单帧预测方式,根据 HRRP 序列的前 16 帧,预测后 1 帧 HRRP。

为提高网络的非线性表征能力,前 3 层 ConvLSTM 层添加 Relu 激活函数。为了防止出现网络梯度的爆炸和消失问题,在每层 ConvLSTM 之后采用批标准化层 (batch normalization, BN),BN 层可以将数据分布变换为标准分布,用于加快网络的训练速度^[15]。

2.2.3 损失函数

一般情况下,对于机器学习中的回归问题通常采用均方误差 M_{MSE} (MSE) 和平均绝对值误差 M_{MAE} (MAE) 等作为损失函数,而二值交叉熵 (binary cross-entropy) 常用于二分类问题。实验过程中发现,采用二值交叉熵作为损失函数,预测效果明显优于 MSE 或 MAE 作为损失函数的情况。

假设采用 MSE 作为损失函数, sigmoid 函数作为激活函数, 则 MSE 损失函数为

$$L_M(y_i, \hat{y}_i) = \frac{1}{M} \sum_{i=1}^M (y_i - \hat{y}_i)^2 = \frac{1}{M} \sum_{i=1}^M [y_i - \sigma(wx_i + b)]^2 = \frac{1}{M} \sum_{i=1}^M \left(y_i - \frac{1}{1 + e^{-(wx_i + b)}} \right)^2 \quad (12)$$

式中: $\sigma(\cdot)$ 为激活函数, y_i 为待预测帧 HRRP 第 i 个距离单元的真实值, \hat{y}_i 为网络模型对于该距离单元的预测值。可知, Loss 函数为非凸函数, 难以获得全局最优解, 会存在梯度消失的情况。

若采用二值交叉熵作为损失函数, sigmoid 作为激活函数, 那么二值交叉熵函数为

$$L_B(y_i, \hat{y}_i) = -\frac{1}{M} \sum_{i=1}^M y_i \cdot \log(\hat{y}_i) + (1 - y_i) \cdot \log(1 - \hat{y}_i) \quad (13)$$

对 \hat{y}_i 求导可得:

$$\frac{\partial L_B(y_i, \hat{y}_i)}{\partial \hat{y}_i} = -\frac{1}{M} \sum_{i=1}^M \frac{y_i - \hat{y}_i}{y_i(1 - \hat{y}_i)} \quad (14)$$

可知, 当 $\hat{y} = y_i$ 时, $L_B(y_i, \hat{y}_i)$ 取得最小值。表明二值交叉熵函数适用于 HRRP 的预测问题。

令 $\hat{y} = y_i, M = 1$, 则 $L_B(y_i, \hat{y}_i)$ 关于 y_i 的函数见图 6。

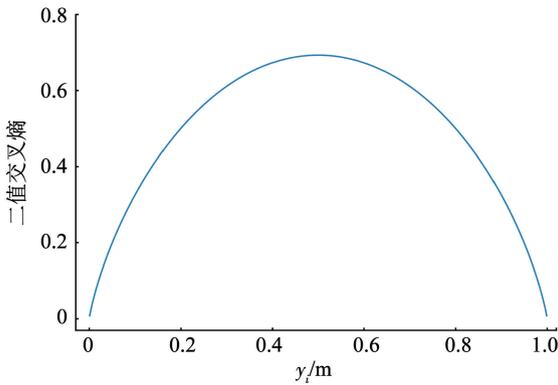


图 6 $\hat{y} = y_i$ 时, 二值交叉熵随 y_i 的变化规律

Fig. 6 Variation law of binary cross-entropy with y_i when $\hat{y} = y_i$

从图 6 中可以看出, 当 $y_i = 0.5$ 时, $L(y_i, \hat{y}_i)$ 取得最大值, 且在 $[0, 1]$ 内, $L(y_i, \hat{y}_i) \geq 0$ 。二值交叉熵值的大小并不能准确反映网络预测效果。因此, 实验中采用二值交叉熵作为损失函数, MAE 作为评价函数。

3 实验与结果分析

3.1 实验设置和数据集建立

为验证 ConvLSTM 网络的有效性, 本文仿真产

生了不同参数空间锥体目标的 HRRP 序列。雷达中心频率设置为 10 GHz, 带宽为 1.5 GHz, 目标距离雷达初始距离为 800 km, 本文采用经典的物理光学法 (PO) 来仿真锥体目标的 RCS。设置雷达信号的极化方式为垂直极化, 信噪比为 10 dB, 噪声类型为高斯白噪声, 每帧一维距离像长度设置为 360 个距离单元, 目标参数设置见表 2。

表 2 实验数据设置

Tab. 2 Experimental data setup

编号	锥体尺寸/ (m × m)	运动速度 $v/(m \cdot s^{-1})$	进动角 $\theta/(^\circ)$	飞行俯仰角 $\varphi/(^\circ)$	成像间隔/ s
1	0.6 × 2.5	2 500	2	4	0.24
2	0.6 × 2.5	2 500	5	4	0.24
3	0.6 × 2.5	2 500	2	5	0.24
4	0.6 × 2.5	2 500	2	4	0.18
5	0.6 × 2.5	2 600	2	4	0.24
6	0.6 × 2.5	2 500	2	10	0.24
7	0.6 × 2.5	2 300	2	4	0.24
8	0.5 × 2.1	2 500	2	4	0.24

鉴于高斯白噪声的随机性, 表 2 中, 在每一种目标参数下重复仿真 10 次, 每次仿真实空间锥体目标运动过程中在成像间隔下的连续 1 000 帧一维距离像。一维距离像仿真结果见图 7, 图 7(a) ~ (h) 分别为表 2 中编号 1 ~ 8 条件下的一维距离像仿真结果, 图中横坐标距离以锥体重心为坐标零点, 幅度经过归一化处理。

初始仿真数据共包含 80 000 个样本。实验中采用前 16 帧 HRRP 序列预测后 1 帧 HRRP 的方式, 本文提出的 ConvLSTM 网络还可以进一步推广至多帧预测场景, 但需要更充分的数据集进行训练。经过数据预处理之后, 总的样本个数为 78 720 个。实验中设置训练集、验证集和测试集样本大小比例为 3:1:1, 即训练集大小为 47 232, 验证集和测试大小为 15 744。

本实验在 Python 环境下利用 Keras 框架实现。损失函数为二值交叉熵, 优化器设置为 Adam, 批大小设置为 64, 迭代次数为 100 次, 共设置 4 层 ConvLSTM 层, 每层 ConvLSTM 层卷积核大小为 (1, 10), 卷积核数量为 30, 网络最后一层为二维卷积层, 卷积核大小为 (1, 10), 卷积核数量为 1。

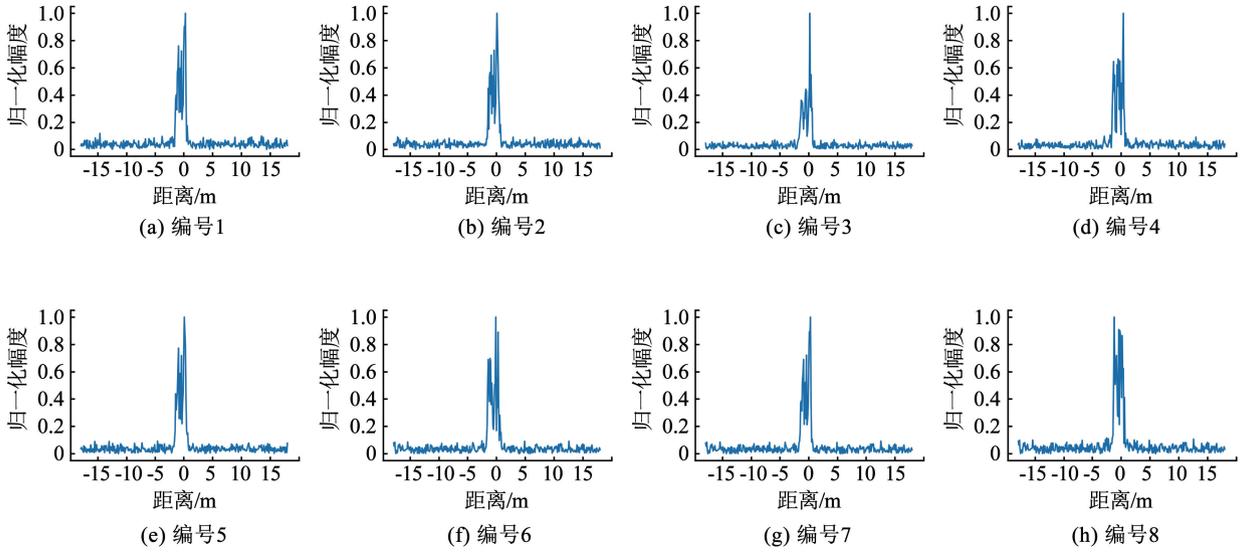


图 7 一维距离像仿真结果

Fig.7 Results of HRRP simulation

3.2 实验评价指标

为客观验证 ConvLSTM 网络预测 HRRP 序列的准确性,采用平均绝对误差 (M_{MAE}) 和皮尔逊相关系数 (r) 对预测结果进行评价分析。

平均绝对误差是所有预测值与真实值之间的绝对误差平均值。

$$M_{MAE} = \frac{1}{M} \sum_{n=1}^M |\hat{y}_i - y_i| \quad (15)$$

式中: y_i 为真实数据值, \hat{y}_i 为预测数据值。

皮尔逊相关系数又称皮尔逊积矩相关系数,常用于度量 2 个变量之间的相关性。

$$r = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X) \text{Var}(Y)}} = \frac{\sum_{i=1}^M (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^M (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^M (Y_i - \bar{Y})^2}} \quad (16)$$

式中 X, Y 为随机变量。

3.3 实验结果与分析

为了对比分析 ConvLSTM 网络模型的性能,本实验在相同的数据集下比较了 ConvLSTM 与二维卷积 2 种深度学习神经网络模型的预测效果,并对 2 种模型预测效果采用平均绝对误差和皮尔逊相关系数评价指标进行评价。其中,二维卷积神经网络预测方法是通过将多帧 HRRP 序列重排列为单通道图像形式^[16],卷积神经网络通过卷积获取数据的时间和空间信息。

从测试集随机抽取 3 个样本,二维卷积网络和 ConvLSTM 网络预测效果如图 8 所示,图 8(a) ~ (d) 分别为 GroundTruth、ConvLSTM 网络和二维卷积神经网络的预测结果以及 2 种网络的预测绝对误差对比。

以上 3 个样本 2 种网络模型对一维距离像峰值位置预测结构见表 3。

可以看出,经典卷积神经网络和 ConvLSTM 网络均能实现 HRRP 序列的预测,相较于经典卷积神经网络,ConvLSTM 网络波峰位置与 GroundTruth 相比更为接近,原因是 ConvLSTM 网络包含 LSTM 网络结构,对时间序列处理能力更强,对于输入的 16 帧 HRRP 数据,经典卷积神经网络对于时间前后信息无差别处理,而 ConvLSTM 网络引入了门控操作,能学习到更多时间维信息,对 HRRP 序列的预测也更加准确。

为了更全面地评价 ConvLSTM 网络对 HRRP 序列的预测能力,在整个测试集上分别计算 2 种网络模型皮尔逊相关系数和平均绝对误差。经典二维卷积神经网络 2 个指标数值分别为 0.953 4 和 0.040 3,而 ConvLSTM 网络模型 2 个指标数值分别为 0.973 1 和 0.033 4。可看出,ConvLSTM 网络的皮尔逊相关系数较经典卷积神经网络更大,而平均绝对误差 M_{MAE} 较经典卷积神经网络更小,说明 ConvLSTM 网络能够更有效地提取 HRRP 序列的特征,并对 HRRP 作出更准确的预测。

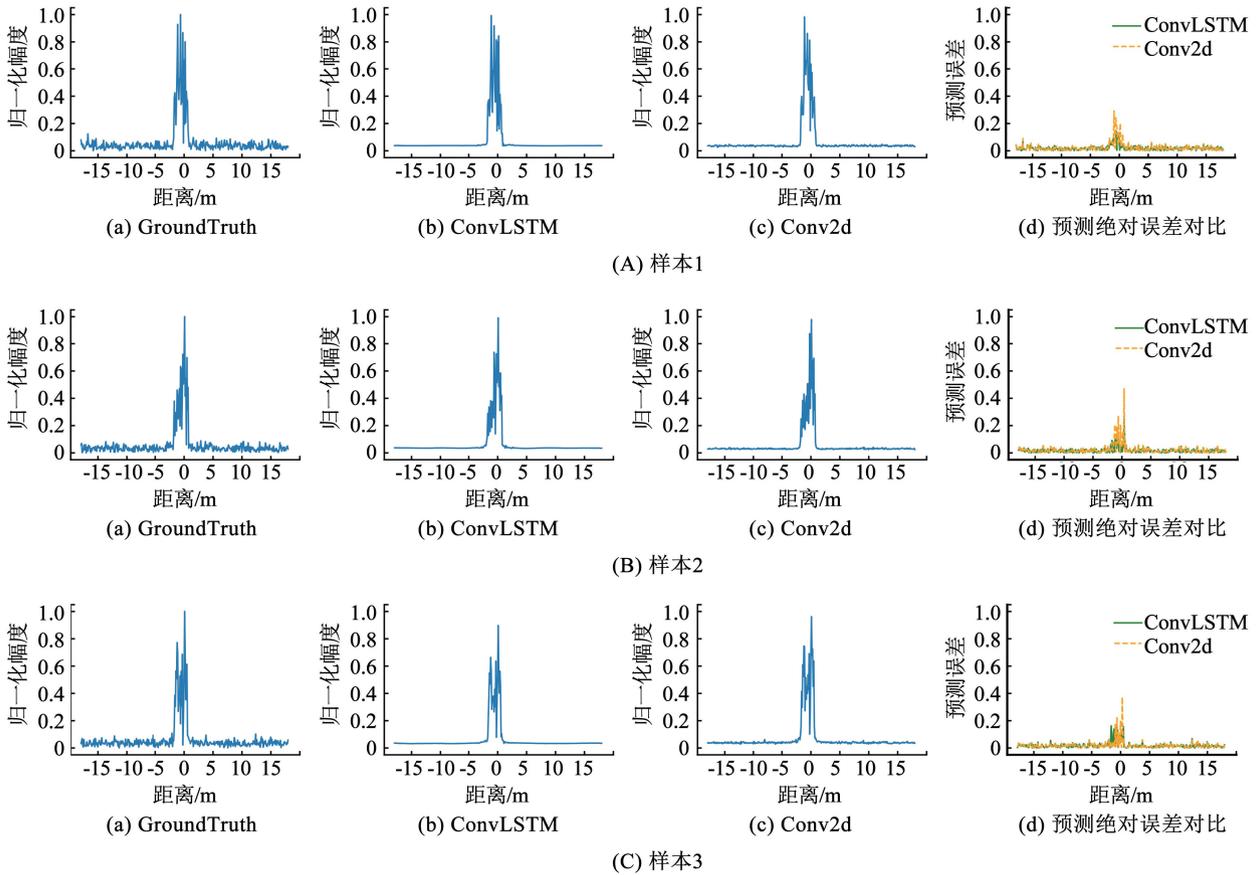


图 8 Conv2d 与 ConvLSTM 模型预测误差对比

Fig. 8 Comparison of prediction errors between Conv2d and ConvLSTM models

表 3 峰值位置预测结果对比

Tab. 3 Comparison of peak position prediction results

网络模型	波峰	样本 1/m	样本 2/m	样本 3/m
GroundTruth	峰值 1	-1.1	-0.9	-1.6
	峰值 2	-0.6	-0.1	-1.2
	峰值 3	-0.2	0.2	-0.7
	峰值 4	0.2	0.6	0.4
Conv2d	峰值 1	-1.1	-0.9	-1.5
	峰值 2	-0.6	-0.2	-1.2
	峰值 3	-0.2	0.2	-0.7
	峰值 4	0.2	0.6	0.5
	误差平均值	0	0.025	-0.05
ConvLSTM	峰值 1	-1.1	-0.9	-1.6
	峰值 2	-0.6	0	-1.2
	峰值 3	-0.2	0.2	-0.7
	峰值 4	0.2	0.6	0.4
	误差平均值	0	-0.025	0

综上所述,可以看出:

1) ConvLSTM 网络模型皮尔逊相关系数和平均绝对误差分别为 0.973 1 和 0.033 4, 具有较高的皮尔逊相关系数和较低的平均绝对误差, 说明

ConvLSTM 网能够实现 HRRP 序列的预测, 并且具有较高的预测精度。

2) 与二维卷积神经网络相比, ConvLSTM 网络模型预测结果更接近于 GroundTruth, 并且皮尔逊相关系数较二维卷积神经网络提高了 0.019 7, 平均绝对误差较二维卷积神经网络降低了 0.006 9, 表明 ConvLSTM 网络能从大量 HRRP 序列数据中学习更多时间和空间信息, 有效提高了数据的利用率。

3) 经典卷积预测结果在噪声基底部分出现明显波纹, 而 ConvLSTM 网络预测结果在噪声基底部分抖动更小, 说明 ConvLSTM 网络能够学习到 HRRP 序列的主要规律, 并抑制高频噪声。

4 结 论

针对空间进动锥体高分辨距离像序列预测问题, 设计了一种基于卷积长短期记忆网络模型的 HRRP 序列预测方法。该网络模型充分利用了卷积神经网络和长短期记忆网络提取空间和时间特性的特性, 将 2 种网络有效结合, 因此 ConvLSTM 网络能够实现 HRRP 序列的预测。实验结果表明, ConvLSTM 网络预测得到的 HRRP 形状与物理光学法计算得到的回波距离像形状非常相似, 且预测数值上具有

很高的精度,具有更高的皮尔逊相关系数和更低的平均绝对误差。

参考文献

- [1] 孙晶明, 虞盛康, 孙俊. 基于深度学习的 HRRP 识别姿态敏感性分析[J]. 系统工程与电子技术, 2022, 44(3): 802
SUN Jingming, YU Shengkang, SUN Jun. Pose sensitivity analysis of HRRP recognition based on deep learning [J]. Journal of Systems Engineering and Electronics, 2022, 44(3): 802. DOI:10.12305/j.issn.1001-506X.2022.03.12
- [2] FANG Xiang, SU Donglin. Automatic target recognition based on sequences of high resolution radar range-profiles[C]//Proceedings of Asia-Pacific Conference on Environmental Electromagnetics. Dalian: Asia-Pacific Conference on Environmental Electromagnetics, 2006: 658. DOI:10.1109/CEEM.2006.258040
- [3] WANG Yizhe, FENG Cunqiang, ZHANG Yongshun, et al. Space precession target classification based on radar high-resolution range profiles [J]. International Journal of Antennas and Propagation, 2019, 2019: 1. DOI:10.1155/2019/8151620
- [4] 韦楠楠, 张兴敢. 利用 HRRP 序列估计弹道中段目标进动频率[J]. 信号处理, 2022, 38(4): 729
WEI Nannan, ZHANG Xinggan. Precession frequency estimation methods of ballistic missiles in midcourse phase based on HRRPs [J]. Journal of Signal Processing, 2022, 38(4): 729. DOI:10.16798/j.issn.1003-0530.2022.04.007
- [5] 查林, 陈大庆, 吴鹏. 基于 HRRP 序列的空间进动目标参数估计方法[J]. 雷达科学与技术, 2020, 18(6): 592
ZHA Lin, CHEN Daqing, WU Peng. Parameter estimation of space precession target based on HRRPs [J]. Radar Science and Technology, 2020, 18(6): 592. DOI:10.3969/j.issn.1672-2337.2020.06.003
- [6] MOULDEN B J. The ecological approach to visual perception (Book Review) [J]. British Journal of Psychology, 1980, 71(1): 176
- [7] 张海庆. 基于 LSTM 循环神经网络的矿用甲烷传感器自校准研究[J]. 煤矿机械, 2022, 43(6): 169
ZHANG Haiqing. Research on self-calibration of mine methane sensor based on LSTM recurrent neural network [J]. Coal Mine Machinery, 2022, 43(6): 169. DOI:10.13436/j.mkjx.202206055
- [8] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735. DOI:10.1007/978-3-642-24797-2_4
- [9] WALKER J, GUPTA A, HEBERT. Dense optical flow prediction from a static image [C]//2015 IEEE International Conference on Computer Vision (ICCV). Washington: IEEE, 2015: 4411. DOI: 10.1109/ICCV.2015.281
- [10] SHI Xingjian, CHEN Zhourong, WANG Hao, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting [J]. Advances in Neural Information Processing Systems, 2015(28): 802
- [11] 黄启桥, 麦雄发, 李玲, 等. 基于 ConvLSTM 的广西短临降水预报[J]. 气象研究与应用, 2021, 42(4): 44
HUANG Qiqiao, MAI Xiongfa, LI Ling, et al. Forecast of short-term precipitation in Guangxi based on ConvLSTM [J]. Journal of Meteorological Research and Application, 2021, 42(4): 44. DOI: 10.19849/j.cnki.CN45-1356/P.2021.4.08
- [12] BAI Xueru, ZHOU Feng, BAO Zheng. High-resolution radar imaging of space targets based on HRRP series [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(5): 2371. DOI:10.1109/TGRS.2013.2260342
- [13] ZHANG Liang, LI Yang, WANG Yanhua, et al. Polarimetric HRRP recognition based on ConvLSTM with self-attention [J]. IEEE Sensors Journal, 2021, 21(6): 7886. DOI:10.1109/JSEN.2020.3044314
- [14] 潘信亮, 张震, 江涛, 等. 基于卷积长短期记忆网络的 NDVI 预测方法研究[J]. 地理信息世界, 2020, 27(2): 62
PAN Xinliang, ZHANG Zhen, JIANG Tao, et al. An approach of the convolutional long short-term memory network for NDVI prediction [J]. Geomatics World, 2020, 27(2): 62. DOI:10.3969/j.issn.1672-1586.2020.02.011
- [15] 谭等泰, 王伟, 王轶群. 治安监控视频中暴力行为的识别与检测[J]. 中国人民公安大学学报(自然科学版), 2021, 27(2): 96
TAN Dengtai, WANG Wei, WANG Yiqun. Recognition and detection of violence in public security surveillance video [J]. Journal of Chinese People's Public Security University (Natural Science Edition), 2021, 27(2): 96. DOI:10.3969/j.issn.1007-1784.2021.02.014
- [16] FUJIMORI K, RAYTCHEV B, KANEDA K, et al. Localization of flying bats from multichannel audio signals by estimating location map with convolutional neural networks [J]. Journal of Robotics and Mechatronics, 2021, 33(3): 515

(编辑 苗秀芝)